

文章编号:1000-4653(2025)02-0025-07

# 基于 IGWO-GMDH 的有效波高预测模型研究

蒋仲廉<sup>1,2</sup>, 梅乃文<sup>3</sup>, 郭建群<sup>1,2,3</sup>, 翁炳昶<sup>4</sup>, 初晓<sup>1,2,3</sup>

(1. 水路交通控制全国重点实验室, 湖北 武汉 430063;

2. 武汉理工大学 国家水运安全工程技术研究中心, 湖北 武汉 430063;

3. 武汉理工大学 交通与物流工程学院, 湖北 武汉 430063;

4. 长江航道规划设计研究院, 湖北 武汉 430040)

**摘要:**海洋波浪具有显著的随机性、非线性特征,有效波高预测对于船舶航行安全、航路规划等具有重要意义。改进灰狼算法(GWO)搜索机制,并将其与基于分组数据处理方法(GMDH)模型相耦合,提出一种有效波高预测模型;结合波高实测数据集验证预测模型精度,探讨模型不同输入参数的权重占比。研究结果表明:相较于经典GMDH模型,所建立的IGWO-GMDH模型预测精度更高,均方误差减小2.65%、均方根误差降低约1.35%、标准差降低2.14%;波浪特征参数与风场数据的权重占比较高,两者组合对于模型预测精度影响较大。所构建的IGWO-GMDH模型可预测分析有效波高,为船舶航行安全、航路规划与优化等研究提供理论支撑。

**关键词:**有效波高; 分组数据处理模型; 改进灰狼优化算法; 搜索机制优化

中图分类号:U676.1; U652.3 文献标志码:A DOI:10.3969/j.issn.1000-4653.2025.02.004

## Application of coupled IGWO-GMDH model in the prediction of significant wave height

JIANG Zhonglian<sup>1,2</sup>, MEI Naiwen<sup>3</sup>, GUO Jianqun<sup>1,2,3</sup>, WENG Bingchang<sup>4</sup>, CHU Xiao<sup>1,2,3</sup>

(1. State Key Laboratory of Maritime Technology and Safety, Wuhan 430063, China;

2. National Engineering Research Center for Water Transport Safety,

Wuhan University of Technology, Wuhan 430063, China; 3. School of Transportation and Logistics Engineering, Wuhan University of Technology, Wuhan, 430063, China;

4. Changjiang Waterway Institute of Planning and Design, Wuhan 430040, China)

**Abstract:** Ocean waves are characterised as random and non-linear. Predicting significant wave height is critical for ensuring the safety of ship navigation and route planning. In the present study, the Grey Wolf optimiser was improved by optimising the search mechanism and coupled it with the Grouping Method Data Handling model to construct an effective significant wave height prediction model. This novel prediction model was validated using a significant wave height dataset. The weights of the different model variables were also explored. The results show that the IGWO-GMDH model is more accurate. The mean square error decreased by 2.65%, and the root mean square error decreased by approximately 1.35%. The standard deviation was reduced by 2.14%. Additionally, the weights of the wave characteristic parameters and the wind field data are relatively high; combining these would significantly impact the model's accuracy. The IGWO-GMDH model will provide more robust predictions of significant wave height and support research into ship navigation safety and route planning and optimisation.

收稿日期:2024-01-30

基金项目:国家自然科学基金项目(52071250; 51709220)

作者简介:蒋仲廉(1986—),男,研究员,博士,研究方向为水路交通安全与环境。E-mail:z.jiang@whut.edu.cn

通信作者:郭建群(1995—),女,博士研究生,研究方向为水路交通信息感知。E-mail:guojianqun@whut.edu.cn

引用格式:蒋仲廉,梅乃文,郭建群,等.基于IGWO-GMDH的有效波高预测模型研究[J].中国航海,2025,48(2):25-31.

JIANG Z L, MEI N W, GUO J Q, et al. Application of coupled IGWO-GMDH model in the prediction of significant wave height[J]. Navigation of China, 2025, 48(2): 25-31. (in Chinese)

**Key words:** significant wave height; grouping method of data processing (GMDH) model; improved grey wolf optimiser; optimisation of search mechanism

波高是指相邻的波峰和波谷间的垂直距离,是描述海洋波浪最重要的特征参数之一。由于海浪各波分量无规则排列特征,通常在波群中按规则确定一部分波作为有效波,统计计算有效波高(Significant Wave Height, SWH)。SWH作为海洋环境监测的重要参数,在海洋工程设计与建造、船舶航行安全保障和防灾减灾等领域具有重要应用价值<sup>[1-2]</sup>。波高观测数据的大量积累,为SWH分析与预测模型研究奠定了数据基础。

近年来,机器学习算法在波高预测模型研究中得到广泛应用,表现出较好的预测精度与效率。THONGNIRAN等<sup>[3]</sup>建立一种基于卷积神经网络与门控循环单元的海流预测模型,从空间中提取特征并识别时间特征的关系;结合2014—2016年泰国沿海高频雷达测波数据,验证了预测模型精度。通过引入一种遗传算法增强的集成学习框架,XU等<sup>[4]</sup>将Bagging和AdaBoost等集成学习技术与决策树、支持向量回归和人工神经网络等机器学习算法相耦合,结合计算流体力学模拟和水槽试验验证集成学习框架的有效性,分析模型的预测精度和泛化能力,为沿海桥梁所受波浪力预测和计算提供支撑。DUOHG等<sup>[5]</sup>采用覆盖不同海底坡度的120个样本数据,训练并建立基于人工神经网络(Artificial Neural Networks, ANNs)的破碎波高预测模型,讨论模型预测精度。RIAZI<sup>[6]</sup>提出一种简单有效的深度神经网络,该网络可结合不同影响因素预测未来潮汐水平,其优点在于简化的输入层、强大的适用性。

在海洋工程领域中,数据处理组合方法(Group Method of Data Handling, GMDH)具有自组织能力、高效的模型优化和适应性强等特征。KIM等<sup>[7-8]</sup>提出一种基于GMDH的波浪预测模型,模型显著改进了近岸波高预测精度,其性能提升约38%;进一步对比分析基于GMDH和ANNs的近岸波浪预测框架,并在日本气象厅、美国国家海洋与大气管理局和欧洲中期天气预报中心的波浪数据集基础上开展测试验证。然而,GMDH存在无法处理某些极端或非正规波浪数据、极度依赖参数设置等问题,尤其当训练数据集未反映上述特征时。针对上述问题,本文提出一种基于改进灰狼优化算法(Improved Grey Wolf Optimizer, IGWO)的GMDH模型,分析模型精度并探讨其在深海水域有效波高预测中的应用。

## 1 模型建立

### 1.1 经典GMDH模型

GMDH是一种复杂系统启发式自组织建模方

法的多层神经网络<sup>[9]</sup>,以多项式为基础的分组数据处理方法。在GMDH神经网络中,由多个最小结构形成的神经元组成一层。结合已产生的神经元,对每一个神经元产生的误差通过迭代算法分析,产生更优的神经元添加到当前层,直到选出最优的神经元。GMDH实现步骤概括如下:

1) 将数据样本集划分为训练集A和测试集B。

2) 建立输入与输出的一般关系。针对非线性系统,设变量为 $x_1, x_2, \dots, x_n$ ,实际输出值为 $y_i$ ,则建立函数关系为

$$y_i = f(x_1, x_2, \dots, x_n) \quad (1)$$

式(1)可由K-G多项式<sup>[9]</sup>进一步改写为

$$y = a + \sum_{i=1}^m b_i x_i + \sum_{i=1}^m \sum_{j=1}^m c_{ij} x_i x_j + \dots \quad (2)$$

式(2)中: $m$ 为多项式的元数,即每个神经元进入模型的变量个数; $a, b$ 和 $c$ 为多项式系数,代表多项式中变量所占权重; $i, j$ 为输入变量的指标。

3) 在GMDH神经网络中,需在具有外补充性质的准则中选择一个或多个作为准则函数 $y_1$ ,以确定最优模型的选择与质量。

4) 通过将 $y_1$ 最小化,即可得到基本GMDH神经网络。

GMDH网络具有较强的自适应性和鲁棒性,可处理高维数据和非线性关系<sup>[10-11]</sup>。

### 1.2 GWO优化算法

灰狼优化算法(Grey Wolf Optimizer, GWO)是从灰狼群体捕食行为启发而提出的一种群智能优化算法<sup>[12]</sup>。其基本原理来自狼群社会中的等级制度,具体可分为4层。

1)  $\alpha$ 层是狼群的领导者,带领整个狼群寻找猎物,代表算法中的最优解。

2)  $\beta$ 层是狼群领导的协助者,协助领导者寻找猎物,代表算法中的次优解。

3)  $\delta$ 层是狼群中的哨兵和侦察兵,听从 $\alpha$ 层和 $\beta$ 层的灰狼进行侦察与放哨,代表算法中适应度差的解。

4)  $\omega$ 层是最底层的狼,围绕前三层的狼进行位置更新,代表算法中其余所有解。

狼群的狩猎过程可分为2个阶段。

#### 1.2.1 包围猎物

在GWO算法中,使用式(3)和式(4)实现位置更新。

$$D = |C \times X_p(t) - X(t)| \quad (3)$$

$$\mathbf{X}(t+1) = \mathbf{X}_p(t) - \mathbf{A} \cdot \mathbf{D} \quad (4)$$

式(3)为灰狼与猎物之间的距离公式;(4)为灰狼位置更新公式; $t$ 为当前迭代次数, $\mathbf{X}_p(t)$ 与 $\mathbf{X}(t)$ 为灰狼与猎物的位置向量; $\mathbf{A}$ 与 $\mathbf{C}$ 为系数向量,有

$$\mathbf{A} = 2\mathbf{a} \times \mathbf{r}_1 - \mathbf{a} \quad (5)$$

$$\mathbf{C} = 2\mathbf{r}_2 \quad (6)$$

式(5)和式(6)中: $\mathbf{r}_1$ 、 $\mathbf{r}_2$ 为随机数向量; $\mathbf{a}$ 为收敛因数,随着 $t$ 的增大在 $[0, 2]$ 线性减小。

### 1.2.2 追捕猎物

由式(3)和式(4)确定猎物位置后, $\beta$ 狼和 $\delta$ 狼在 $\alpha$ 狼的指挥下包围猎物。使用式(7)、式(8)和式(9)对全体灰狼进行位置更新,式(10)、式(11)、式(12)和式(13)实现 $\omega$ 狼位置调整与计算,有

$$\mathbf{D}_\alpha = |\mathbf{C}_1 \cdot \mathbf{X}_\alpha - \mathbf{X}| \quad (7)$$

$$\mathbf{D}_\beta = |\mathbf{C}_2 \cdot \mathbf{X}_\beta - \mathbf{X}| \quad (8)$$

$$\mathbf{D}_\delta = |\mathbf{C}_3 \cdot \mathbf{X}_\delta - \mathbf{X}| \quad (9)$$

$$\mathbf{X}_1 = |\mathbf{X}_\alpha - \mathbf{A}_1 \times \mathbf{D}_\alpha| \quad (10)$$

$$\mathbf{X}_2 = |\mathbf{X}_\beta - \mathbf{A}_2 \times \mathbf{D}_\beta| \quad (11)$$

$$\mathbf{X}_3 = |\mathbf{X}_\sigma - \mathbf{A}_3 \times \mathbf{D}_\sigma| \quad (12)$$

$$\mathbf{X}(t+1) = \frac{\mathbf{X}_1 + \mathbf{X}_2 + \mathbf{X}_3}{3} \quad (13)$$

## 1.3 IGWO-GMDH 耦合模型

超参数(如选择压力、隐藏层数等)对模型预测效率和精度有显著影响。经典 GMDH 通过最小二乘法计算最优参数,主要适用于线性问题;对于非线性样本数据,其超参数计算方法可能失效。作为常见的优化算法,GWO 具有较强的非线性处理能力,但收敛速度慢、全局搜索能力较差。针对上述问题,本文提出基于维度的改进狩猎策略、非线性收敛因数和随机扰动的更新策略,构建 IGWO-GMDH 耦合模型,提升经典 GMDH 模型的非线性数据处理能力,增强耦合模型的鲁棒性。

### 1.3.1 基于维度的改进狩猎策略

在经典 GWO 算法中,所有的维度都会更新其位置信息;基于维度的改进策略是指在每次迭代中,只有一部分维度会根据领导者的位置更新,提高搜索的多样性、避免过早收敛。通过在位置更新公式中引入一个随机选择的维度掩码,实现掩码选中的维度的位置更新。

假设有一个维度掩码 $\mathbf{M}$ ,每个元素 $M_i$ 从 $\{0, 1\}$ 中随机选取,则位置更新公式可表示为

$$\mathbf{X}(t+1) = \mathbf{M} \odot (\mathbf{X}_p(t) - \mathbf{A} \cdot \mathbf{D}) + (1 - \mathbf{M}) \odot \mathbf{X}(t) \quad (14)$$

式(14)中: $\odot$ 为元素乘法;当 $M_i = 1$ 时,维度 $i$ 进行

更新。

采用上述改进维度狩猎策略,可平衡算法的全局搜索和局部搜索能力,避免过早收敛,提高 GWO 算法优化效率。

### 1.3.2 非线性收敛因数与随机扰动更新策略

在经典 GWO 算法迭代过程中,线性收敛因数忽略了不同阶段解的变化,对于复杂、多峰优化问题,易陷入局部最优解。为改进控制算法收敛速度与搜索范围,提高模型效率和鲁棒性,本文提出非线性收敛因数更新策略为

$$\mathbf{a} = \mathbf{a}_1 - \mathbf{a}_1 \times \left[ \frac{1}{e - 1} \times (e^{\frac{i}{i_{\max}}} - 1) \right] \quad (15)$$

式(15)中: $\mathbf{a}_1$ 为收敛因数的初始值; $i$ 为迭代次数; $i_{\max}$ 为最大迭代次数。

收敛因数随迭代次数变化曲线见图 1。由图 1 可知:当迭代次数接近峰值时,曲线呈现加速下降趋势;因此,上述更新策略有助于跳出局部最优解。通过在一定概率下添加随机扰动,可扩大算法搜索空间,增加寻得全局最优解的概率。同时,随机扰动可在算法迭代后期增加种群多样性,为摆脱局部收敛创造有利条件。引入扰动因数,对位置向量更新为

$$\mathbf{X}_1 = |\mathbf{X}_\alpha - \mathbf{A}_1 \times \mathbf{D}_\alpha + \boldsymbol{\eta} \times \mathbf{r}| \quad (16)$$

$$\mathbf{X}_2 = |\mathbf{X}_\beta - \mathbf{A}_2 \times \mathbf{D}_\beta + \boldsymbol{\eta} \times \mathbf{r}| \quad (17)$$

$$\mathbf{X}_3 = |\mathbf{X}_\sigma - \mathbf{A}_3 \times \mathbf{D}_\sigma + \boldsymbol{\eta} \times \mathbf{r}| \quad (18)$$

式(16)~式(18)中: $\boldsymbol{\eta}$ 为扰动因数; $\mathbf{r}$ 为 $[0, 1]$ 区间正态分布的随机值;通过调整扰动概率和幅度,可优化算法不同阶段的搜索能力和收敛程度。

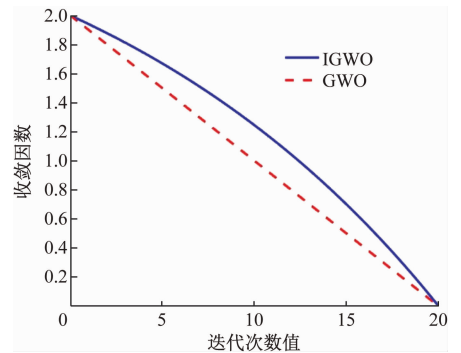


图 1 收敛因数随迭代次数变化曲线

Fig. 1 Variations of convergence factor with iterations

### 1.3.3 耦合模型

将 IGWO 算法与经典 GMDH 网络相耦合,实现步骤如下。

1) 初始化群体:随机生成一群灰狼(解决方案的候选者),灰狼随机分布在搜索空间中,为每匹狼分配一个初始位置。

2) 狼群追猎、更新位置:狼群根据领头狼的位

置更新自己的位置,以接近最优解;检查位置边界,以确保狼群的搜索范围在预定边界内。

3) GMDH 模型建立:利用当前解作为参数输入建立 GMDH 网络,并划分数据集进行训练和预测。

4) 迭代更新:结合 IGWO 的改进狩猎策略与参数改进,重复执行狼群的追猎、GMDH 网络的优化和狼群的更新,直到满足停止条件(如达到预定的迭代次数或解的质量)。

5) 输出最终解:输出适应度最高的解,即给定问题的最优解或近似最优解。

## 2 数据集构建

### 2.1 数据来源与预处理

本文研究数据集来源于美国国家海洋和大气管理局服务器(<https://www.ndbc.noaa.gov/>),选取大西洋近海的 44 013 号站点(42°20'44"N,70°39'4"W)。采用不同环境变量,构建 SWH 预测模型;主要环境变量包括风向(MWD)、风速(WSPD)、峰值 5 s 或 8 s 阵风速度(GST)、优势波周期(DPD)、平均波周期(APD)、海平面气压(PRES)和海水温度(WTMP)。数据集的时间跨度为 2020 年 1 月 1 日—2022 年 12 月 31 日,数据采样间隔为 1 h。

通过对小时观测数据进行预处理(包括剔除离群点、滑动平均去噪等),获得合计 25 038 条数据;取前 80% 数据建立模型训练集,剩余 20% 作为模型测试集。

### 2.2 性能评估指标

为定量评估模型预测精度和误差分布,本文引入误差评价指标,包括:均方误差(Mean Squared Error,  $S_{ME}$ )、均方根误差(Root Mean Squared Error,  $S_{RME}$ )、平均误差(Mean Error,  $M_E$ )、标准差(Standard Deviation,  $S_D$ )和相关系数(Correlation Coefficient,  $R$ ),其计算公式为

$$S_{ME} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (19)$$

$$S_{RME} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (20)$$

$$M_E = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i) \quad (21)$$

$$S_D = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2} \quad (22)$$

$$R = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (23)$$

式(19)~式(23)中: $\hat{y}_i$ 和 $y_i$ 分别为第 $i$ 时刻的模型预测值和实际观测值; $\bar{\hat{y}}$ 为预测值的平均值。

## 3 结果与讨论

### 3.1 模型预测结果分析

有效波高预测结果对比见图 2。由图 2 可知:GMDH 和 IGWO-GMDH 模型在有效波高预测中整体趋势相似;模型训练集和测试集性能对比见表 1 和表 2。相较于 GMDH,IGWO-GMDH 耦合模型的各项指标均有不同程度提升, $S_{ME}$ 减小 2.65%、 $S_{RME}$ 降低约 1.35%和  $S_D$ 降低 2.14%。

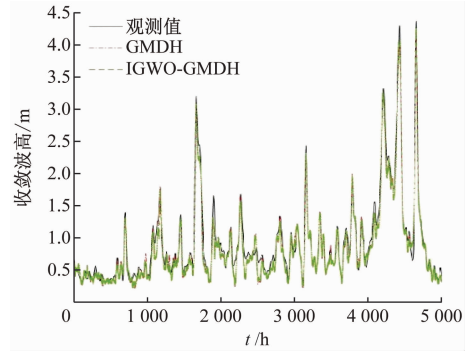


图 2 有效波高预测结果对比

Fig. 2 Comparison of significant wave height predictions

表 1 GMDH 与 IGWO-GMDH 训练集性能对比

Tab. 1 Model performance comparison between GMDH and IGWO-GMDH for training dataset

评估指标	GMDH	IGWO-GMDH
$S_{ME}/m^2$	0.020 510 0	0.019 220 0
$S_{RME}/m$	0.141 200 0	0.138 600 0
$M_E/m$	0.000 861 9	0.000 827 4
$S_D/m$	0.143 200 0	0.138 700 0
$R$	0.976 600 0	0.978 100 0

表 2 GMDH 与 IGWO-GMDH 测试集性能对比

Tab. 2 Model performance comparison between GMDH and IGWO-GMDH for testing dataset

评估指标	GMDH	IGWO-GMDH
$S_{ME}/m^2$	0.015 85	0.015 43
$S_{RME}/m$	0.125 90	0.124 20
$M_E/m$	0.065 08	0.065 77
$S_D/m$	0.107 70	0.105 40
$R$	0.987 40	0.987 60

GMDH 和 IGWO-GMDH 模型有效波高预测结果回归分析见图 3。图 3 中:IGWO-GMDH 模型预测

结果分布更为集中,相关系数  $R$  值高于 GMDH 模型,表明 IGWO-GMDH 在有效波高预测中精度更高,与表 1、表 2 所述结果一致。

适应度通常指模型在特定任务中的性能或效能。在 GWO 算法中,适应度值常用于指导搜索过程,狼群会根据适应度值的高低进行更新和调整,以寻求最优解。拥有较高适应度值的解决方案常被视为更优,因此算法倾向于探索上述解决方案附近的区域。GMDH 与 IGWO-GMDH 模型适应度值变化

曲线见图 4,由于算法第一代种群的选择是完全随机的,对适应度值产生较大影响,故忽略不计。IGWO-GMDH 耦合模型的适应度误差值、收敛速度均优于 GMDH,研究表明:耦合模型在实际问题求解中寻得最优解(或近似最优解)的速度优于 GMDH 模型;添加随机扰动的更新策略,可有效避免收敛速度过快而陷入局部最优的问题,对于复杂问题求解具有重要意义。

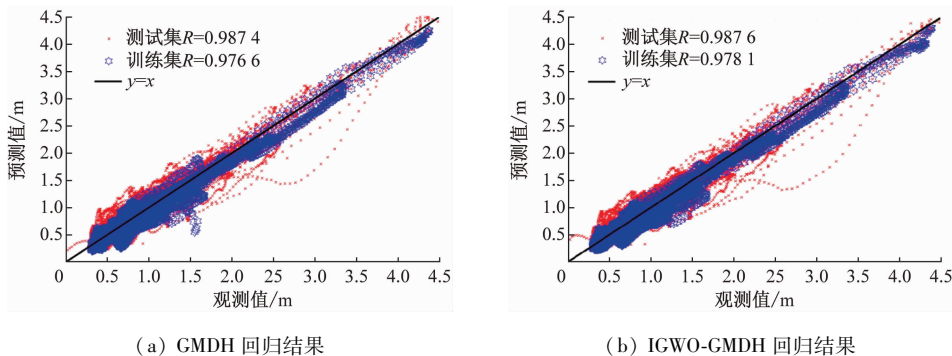


图 3 GMDH 与 IGWO-GMDH 模型有效波高预测结果回归分析

Fig. 3 Regression analysis of significant wave prediction for GMDH and IGWO-GMDH

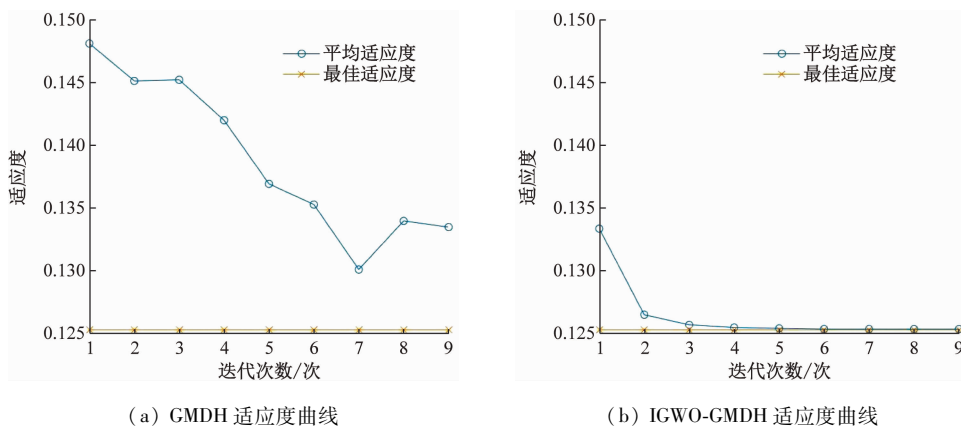


图 4 GMDH 与 IGWO-GMDH 模型适应度变化曲线

Fig. 4 Variation of fitness for GMDH and IGWO-GMDH

### 3.2 模型敏感度分析

皮尔逊相关系数 (Pearson Correlation Coefficient,  $r$ ) 常用于度量 2 个变量之间线性相关程度,其取值范围为  $[-1, 1]$ ;  $|r|$  值越接近 1,则 2 个变量间的相关性越强。皮尔逊相关系数计算公式为

$$r = \frac{\text{Cov}(x, y)}{\sqrt{\text{Var}[x] \text{Var}[y]}} \quad (24)$$

式(24)中:  $\text{Cov}(x, y)$  为变量  $x$  和变量  $y$  的协方差;  $\text{Var}[x]$  和  $\text{Var}[y]$  分别为变量  $x$  和变量  $y$  的方差。通过计算第 2.1 节所述各变量之间的相关系数见图 5。由图 5 可知: WSPD、DPD、MWD、PRES、WTMP 与

SWH 相关性较低,而 GST、APD 与 SWH 存在较强相关性; GST 与 APD 间的相关系数仅为  $-0.04326$ ,可视为相互独立。以上述参数作为预测模型的输入变量,则 IGWO-GMDH 预测模型的  $S_{\text{RME}}$  和  $R$  值分别为  $0.1571 \text{ m}$  和  $0.9794$ 。

基于皮尔逊相关系数对模型输入变量权重进行排序,输入参数权重值见图 6a,其中 GST、APD 所占权重最高,与图 5 所示结论基本一致。XIE 等<sup>[13]</sup>研究表明:输入变量 MWD、PRES 和 WTMP 等对模型预测精度影响不大;宋巍等<sup>[14]</sup>通过计算皮尔逊相关系数,得到 GST、APD 与有效波高相关性最高的结

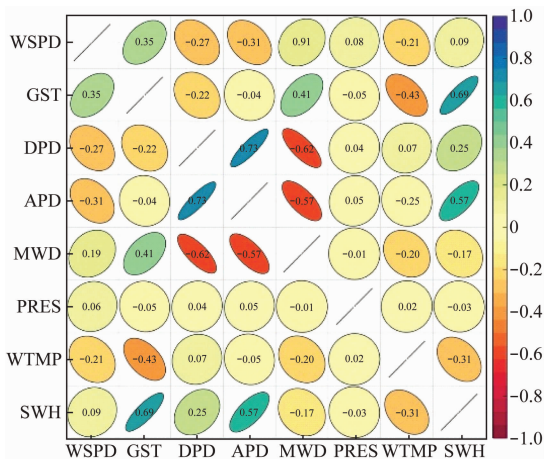
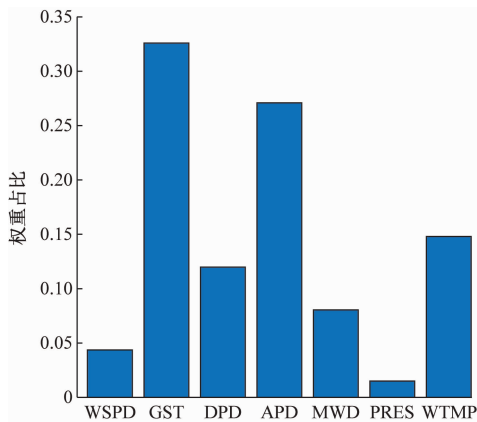


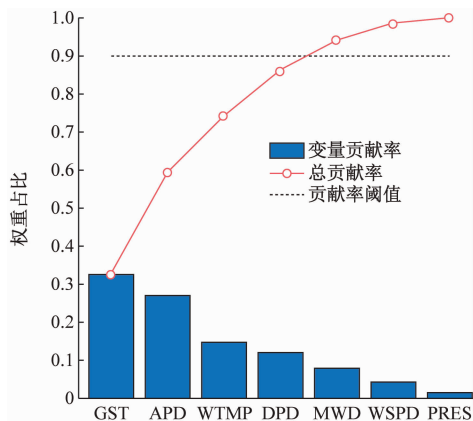
图5 模型输入参数皮尔逊相关系数热力图

Fig. 5 Pearson correlation coefficient heat map of the model input parameters

论;金权<sup>[15]</sup>通过支持向量机构建的模型研究表明风场、波浪特征参数对于模型预测精度影响较大。本文研究结果与文献[13]~文献[15]基本一致,通过选取少数关键输入变量,预测模型精度可达到较高水平,各参数贡献率见图6b。因此,当观测资源或



(a) 输入参数权重值



(b) 各参数贡献率

图6 IGWO-GMDH模型输入参数权重与贡献率计算

Fig. 6 Weights of model input parameters and contribution rate calculation

数据集相对有限时,应聚焦于核心关键变量,以保证预测模型精度。

## 4 结束语

海洋波浪对于通航安全保障、船舶航行风险评估等具有重要参照价值,其中有效波高是描述海浪最重要的特征参数之一。本文提出基于维度的改进狩猎策略、非线性收敛因数和随机扰动的更新策略,构建基于IGWO-GMDH的有效波高预测模型,利用深海水域波高观测数据集测试验证模型的精度与鲁棒性,得到主要结论如下:

1) 与GMDH模型相比,IGWO-GMDH模型具有更优的预测精度;其中 $S_{ME}$ 减小2.65%、 $S_{RME}$ 降低约1.35%、 $S_D$ 降低2.14%。

2) 通过计算不同输入变量的相关系数可知:以GST、APD等为代表的风场和波浪特征参数,对模型预测精度影响较大。因此,当观测资源或数据集相对有限时,上述变量可作为预测模型的重要输入参数。

3) 基于维度的改进狩猎策略、非线性收敛因数和随机扰动的更新策略,有效避免了经典GWO算法过早收敛、陷入局部最优等问题,对于优化GMDH模型超参数、拓展GWO算法应用等具有重要意义。

## 参考文献

- [1] 刘大刚,解以扬,刘斌贤,等.大风浪条件下船舶风险状况动态评估预警系统[J].中国航海,2015,38(1):63-67.  
LIU D G, XIE Y Y, LIU B X, et al. Dynamic risk evaluation and early warning system for vessels under rough sea condition[J]. Navigation of China, 2015, 38(1): 63-67. (in Chinese)
- [2] 侯慷,黄志扬,支远哲.中长周期波浪条件下船舶航迹带宽度研究[J].港工技术,2021,58(1):22-26.  
HOU K, HUANG Z Y, ZHI Y Z. Study on navigation track width under medium and long period waves[J]. Port Engineering Technology, 2021, 58(1): 22-26. (in Chinese)
- [3] THONGNIRAN N, VATEEKUL P, JITKAJORNWANICH K, et al. Spatio-temporal deep learning for ocean current prediction based on HF radar data[C]//2019 16th International Joint Conference on Computer Science and Software Engineering (JCSSE). Thailand: Chonburi, 2019.
- [4] XU G, WEI H, XUE S, et al. Predicting wave forces on coastal bridges using genetic algorithm enhanced ensemble learning framework[J]. Ocean Engineering,

- 2022, 266;1-17.
- [5] DUONG N T, TRAN K Q, LUU L X, et al. Prediction of breaking wave height by using artificial neural network-based approach [J]. *Ocean Modelling*, 2023, 182: 1-15.
- [6] RIAZI A. Accurate tide level estimation: a deep learning approach [J]. *Ocean Engineering*, 2020, 198: 1-11.
- [7] KIM S, TAKEDA M, MASE H. GMDH-based wave prediction model for one-week nearshore waves using one-week forecasted global wave data [J]. *Applied Ocean Research*, 2021, 117;1-22.
- [8] KIM S, TOM T H A, TAKEDA M, et al. A framework for transformation to nearshore wave from global wave data using machine learning techniques: validation at the port of hitachinaka, Japan [J]. *Ocean Engineering*, 2021, 221(1): 1-13.
- [9] LEMKE F, MÜLLER J A. Self-organising data mining [J]. *Systems Analysis Modelling Simulation*, 2003, 43(2): 231-240.
- [10] 陈厚积,胡晓兵,邓希. 基于 GMDH 的宏观经济短期预测模型[J]. *四川大学学报(自然科学版)*, 2020, 57(5): 915-919.
- CHEN H J, HU X B, DENG X. A short-term macroeconomic forecasting model based on GMDH [J]. *Journal of Sichuan University (Natural Science Edition)*, 2020, 57(5): 915-919. (in Chinese)
- [11] 肖进,孙海燕,刘敦虎,等. 基于 GMDH 混合模型的能源消费量预测研究 [J]. *中国管理科学*, 2017, 25(12): 158-166.
- XIAO J, SUN H Y, LIU D H, et al. GMDH based hybrid model for China's energy consumption predictor [J]. *Chinese Journal of Management Science*, 2017, 25(12): 158-166. (in Chinese)
- [12] ZHANG S, ZHOU Y. Grey wolf optimizer based on powell local optimization method for clustering analysis [J]. *Discrete Dynamics in Nature and Society*, 2015: 1-17.
- [13] XIE J, XUE X. A novel hybrid model based on grey wolf optimizer and group method of data handling for the prediction of monthly mean significant wave heights [J]. *Ocean Engineering*, 2023, 284: 1-15.
- [14] 宋巍,赵劭,贺琪,等. 多要素局部-全局特征关联的有效波高预测模型 [J]. *上海海洋大学学报*, 2023, 32(3): 669-679.
- SONG W, ZHAO M, HE Q, et al. A prediction model of significant wave height based on local and global correlation of multi-elements [J]. *Journal of Shanghai Ocean University*, 2023, 32(3): 669-679. (in Chinese)
- [15] 金权. 基于机器学习算法对海浪波高的预测及优化研究 [D]. 青岛: 自然资源部第一海洋研究所, 2019.
- JIN Q. Prediction and optimization of machine wave height based on machine learning algorithm [D]. Qingdao: First Institute of Oceanography, Ministry of Natural Resources. (in Chinese)